

Procjena kalorijske vrijednosti iz slika hrane pomoću nadziranog strojnog učenja

Petrović, Danilo

Undergraduate thesis / Završni rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:200:372631>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-12-22**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA OSIJEK**

Sveučilišni prijediplomski studij Računarstvo

**PROCJENA KALORIJSKE VRIJEDNOSTI IZ SLIKA
HRANE POMOĆU NADZIRANOG STROJNOG UČENJA**

Završni rad

Danilo Petrović

Osijek, 2024.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**Obrazac Z1P: Obrazac za ocjenu završnog rada na sveučilišnom prijediplomskom studiju****Ocjena završnog rada na sveučilišnom prijediplomskom studiju**

Ime i prezime pristupnika:	Danilo Petrović
Studij, smjer:	Sveučilišni prijediplomski studij Računarstvo
Mat. br. pristupnika, god.	R4557, 27.07.2020.
JMBAG:	0165086593
Mentor:	doc. dr. sc. Dražen Bajer
Sumentor:	dr. sc. Mario Dudjak
Sumentor iz tvrtke:	
Naslov završnog rada:	Procjena kalorijske vrijednosti iz slika hrane pomoću nadziranog strojnog učenja
Znanstvena grana završnog rada:	Umjetna inteligencija (zn. polje računarstvo)
Zadatak završnog rada:	U radu je potrebno opisati problem procjene kalorijske vrijednosti iz slika hrane kao regresijski problem u području nadziranog strojnog učenja. Potrebno je istražiti relevantnu literaturu kako bi se utvrdio uobičajeni tijek izrade modela koji predviđa kalorijsku vrijednost namirnica sa slike, s naglaskom na postupke za izdvajanje i odabir značajki te algoritme za regresiju. U praktičnom dijelu rada nužno je razviti programsko rješenje koje izdvaja određene značajke iz slike hrane te na temelju njih gradi odgovarajući regresijski model za procjenu kalorijske vrijednosti. Uz to, potrebno je implementirati odgovarajuće postupke za
Datum prijedloga ocjene završnog rada od strane mentora:	18.09.2024.
Prijedlog ocjene završnog rada od strane mentora:	Dobar (3)
Datum potvrde ocjene završnog rada od strane Odbora:	25.09.2024.
Ocjena završnog rada nakon obrane:	Dobar (3)
Datum potvrde mentora o predaji konačne verzije završnog rada čime je pristupnik završio sveučilišni prijediplomski studij:	26.09.2024.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK****IZJAVA O IZVORNOSTI RADA**

Osijek, 26.09.2024.

Ime i prezime Pristupnika:

Danilo Petrović

Studij:

Sveučilišni prijediplomski studij Računarstvo

Mat. br. Pristupnika, godina upisa:

R4557, 27.07.2020.

Turnitin podudaranje [%]:

4

Ovom izjavom izjavljujem da je rad pod nazivom: **Procjena kalorijske vrijednosti iz slika hrane pomoću nadziranog strojnog učenja**

izrađen pod vodstvom mentora doc. dr. sc. Dražen Bajer

i sumentora dr. sc. Mario Dudjak

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.

Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis pristupnika:

SADRŽAJ

1. UVOD	1
1.1. Zadatak završnog rada	2
2. PROCJENA KALORIJSKE VRIJEDNOSTI IZ SLIKA HRANE	3
2.1. Uvod u problem	3
2.2. Regresija kao zadatak nadziranog strojnog učenja	5
2.3. Pregled literature.....	7
2.4. Kritički osvrt.....	9
3. OSTVARENO PROGRAMSKO RJEŠENJE	11
3.1. Izrada skupa podataka.....	11
3.2. Odabir algoritama za procjenu kalorijske vrijednosti	13
3.3. Postupci za izdvajanje značajki.....	14
3.4. Predobrada skupa podataka odabirom značajki	15
4. EKSPERIMENTALNA ANALIZA I REZULTATI.....	17
4.1. Postavke i metodologija eksperimentalne analize	17
4.2. Usporedba postupaka za izdvajanje značajki	19
4.3. Usporedba algoritama za procjenu kalorijskih vrijednosti.....	20
4.4. Analiza učinka odabira značajki	22
5. ZAKLJUČAK.....	25
LITERATURA	27
SAŽETAK.....	29
ABSTRACT	30
ŽIVOTOPIS.....	31
PRILOZI	32

1. UVOD

U današnjem „ubrzanom” svijetu, održavanje zdravih prehrambenih navika i redovite tjelesne aktivnosti predstavlja poseban izazov, ali je isto tako ključno u očuvanju zdravlja pojedinca. Zdravstvene organizacije diljem svijeta naglašavaju važnost uravnotežene prehrane i aktivnog načina života kao glavnih čimbenika u prevenciji mnogih kroničnih bolesti, poput pretilosti, dijabetesa, kardiovaskularnih bolesti i sl. Međutim, obveze na poslu i privatne odgovornosti često dovode do zanemarivanja ovog dijela života. Kao rezultat, ljudi sve manje imaju vremena ili volje za praćenje unosa kalorija i kvalitetu obroka, što dugoročno može negativno utjecati na njihovo zdravlje.

S obzirom na sve veću dostupnost tehnologije, javila se potreba za razvojem alata koji omogućuju automatizirano praćenje unosa hrane putem jednostavnih metoda, poput fotografiranja obroka. Procjena kalorijske vrijednosti hrane iz slika postala je važna jer omogućava korisnicima brže i jednostavnije praćenje prehrane bez potrebe za ručnim unosom podataka. Ova tehnologija osobito je korisna za ljude koji žele izgubiti višak kilograma, sportaše koji prate unos raznih nutritivnih vrijednosti, kao i za osobe s medicinskim stanjima poput dijabetesa koji zahtijevaju strogu kontrolu unosa hrane. Osim toga, takvi alati mogu pomoći nutricionistima i zdravstvenim stručnjacima u personalizaciji prehrambenih planova, što doprinosi preciznijoj brizi za zdravlje pacijenata.

Ovaj radi se bavi problemom procjene kalorijske vrijednosti obroka pomoću slika koristeći metode nadziranog strojnog učenja. Cilj ovog rada je istražiti različite pristupe koji se koriste za rješavanje problema procjene kalorijske vrijednosti hrane putem digitalnih slika, analizirati postojeće metode te predložiti efikasno rješenje korištenjem prilagođenog podatkovnog skupa. Specifično, rad je zasnovan na novom podatkovnom skupu koji je razvijen posebno za potrebe ovog istraživanja, a koji sadrži slike namirnica i obroka s pripadajućim oznakama kalorijske vrijednosti za svaku sliku.

Kroz rad se obrađuju ključni pojmovi strojnog učenja, uključujući metode obrade slika i mjere vrednovanja. U uvodnom poglavlju detaljno je opisan problem procjene kalorijske vrijednosti iz slika hrane te su postavljene temeljne smjernice istraživanja. Pregled literature i kritički osvrt prikazuju različite pristupe koje su drugi autori koristili u rješavanju sličnih problema. Sljedeće poglavlje bavi se programskim rješenjem razvijenim u svrhu ove procjene, s posebnim naglaskom na izradu podatkovnog skupa, korištene algoritme za procjenu kalorijskih vrijednosti te izdvajanje i odabir značajki. Eksperimentalna analiza, predstavljena u posebnom poglavlju, uključuje postavke i metodologiju provedene analize te usporedbu različitih algoritama i metoda izdvajanja

značajki. Na kraju rada nalazi se zaključak koji prikazuje rezultate istraživanja, predlaže smjernice za buduća poboljšanja te daje pregled korištene literature koja je podržala teorijske i praktične dijelove rada. Na kraju, cilj ovog rada je ponuditi potencijalno rješenje koje će pomoći korisnicima da jednostavno i efikasno prate unos kalorija, a time doprinijeti poboljšanju zdravih životnih navika u suvremenom društvu.

1.1. Zadatak završnog rada

Zadatak završnog rada je istražiti metode za procjenu kalorijske vrijednosti hrane na temelju slika koristeći nadzirano strojno učenje. U okviru rada bit će analizirani postojeći pristupi, razvijen specifičan podatkovni skup te implementirano programsko rješenje koje omogućuje automatiziranu procjenu kalorija. Kroz analizu rezultata evaluirat će se učinkovitost predloženog rješenja u svrhu poboljšanja praćenja prehrambenih navika korisnika.

2. PROCJENA KALORIJSKE VRIJEDNOSTI IZ SLIKA HRANE

Procjena kalorijske vrijednosti iz slika hrane predstavlja izazov jer zahtijeva prepoznavanje vrste i količine hrane te procjenu njezine nutritivne vrijednosti. Unutar ovog odlomka, detaljno je opisan problem procjene kalorijske vrijednosti hrane. Pored toga, objašnjene su metode pristupa navedenom problemu, tj. na koje sve načine ga se pokušalo riješiti. Također, s ciljem boljeg razumijevanja teksta, pojašnjeni su osnovni koncepti unutar strojnog učenja, mjere vrednovanja te pregled korištene literature za ovaj rad.

2.1. Uvod u problem

Sama procjena kalorijske vrijednosti odnosi se na izračunavanje količine kalorija u određenom obroku. Kalorija je zastarjela mjerna jedinica topline koja je predstavljala toplinu potrebnu da se gram vode zagrije za 1 °C. Pored toga, ista jedinica se rabi za izražavanje energijske vrijednosti hrane. Glavni ciljevi praćenja dnevnog unosa kalorija su vezani uz zdravlje i izgled pojedinca. Na primjer, ukoliko osoba želi izgubiti višak kilograma, mora unositi manje kalorija u odnosu na količinu koju troši. Također, ako su prisutni zdravstveni problemi kao što su dijabetes, kardiovaskularne bolesti i slično, kontrola unosa kalorija i vrste hrane je od koristi za borbu protiv istih.

Prilikom procjene kalorijske vrijednosti iz slika hrane, možemo susresti razne prepreke i cjelokupni postupak može biti izazovan iz mnogobrojnih razloga. Na primjer, postoji mogućnost da se na slici neki prehrambeni predmet ne vidi (nalazi se skriven ispod nekog drugog objekta, npr. komadi krumpira ispod nekakvog burgera i sl.). Pored toga, slikovni prikaz obroka čiju kalorijsku vrijednost treba procijeniti ne daje dovoljno informacija o načinu pripreme (porijeklo sastojaka, njihova kvaliteta, nutritivna vrijednost svakog sastojka, količina ulja za pripremu itd.), što dovodi do razlika u procjeni i nutritivnoj vrijednosti. Ukoliko je korišten pristup procjene volumena obroka, posao može postati poprilično složen i zahtjevan za implementaciju dobrog rješenja.

Za navedeni problem postoje razna rješenja. Ukoliko se ne koriste tehnološka rješenja, ustaljena je metoda samostalnog mjerenja mase svim sastojcima koji se koriste u pripremi hrane te ručno računanje broja kalorija i ostalih nutritivnih vrijednosti. Postoje javno dostupne nutritivne tablice koje izražavaju kalorijsku vrijednost neke namirnice po njezinoj masi, stoga se vaganjem i čitanjem iz tablice može izračunati kalorijska vrijednost obroka. Isto tako, razgovor sa nutricionistima na tu temu je također dobar pristup. Međutim, ovi pristupi su ili vremenski ili financijski zahtjevni, što dovodi do smanjenja zainteresiranosti za zdrave prehrambene navike

pojedince. Zbog toga, automatizacija procesa procjene putem slika hrane je od velikog značaja, jer doprinosi brzini, smanjenju pogrešaka u unosu podataka zbog ljudske pogreške te većoj pristupačnosti.

Jedan od najzanimljivijih i najinovativnijih pristupa rješavanju ovog problema je korištenje slika hrane za automatsku procjenu kalorijske vrijednosti. Ovaj pristup koristi napredak u računalnom vidu i strojnom učenju kako bi procijenio nutritivne vrijednosti hrane na temelju fotografija obroka.

Brojni radovi i istraživanja pokazuju napredak u području procjene kalorija korištenjem strojnog učenja. Na primjer, istraživanje koje je provedeno u [1] pokazuje kako kombinacija segmentacije slike i regresije može poboljšati preciznost procjene volumena i kalorija hrane.

S razvojem tehnologije, došlo je i do razvoja algoritama za računalni vid koji mogu analizirati slike hrane i procijeniti njihove kalorijske vrijednosti. Kada se razmatraju različite metode za procjenu kalorijske vrijednosti hrane na temelju slika, postoji nekoliko ključnih koraka koji uključuju složene tehnike obrade slike i strojno učenje. Prvi način rješavanja često uključuje prepoznavanje objekata na slici. Korištenje dubokog učenja (engl. *deep learning*) omogućava visoku točnost u prepoznavanju hrane, ali zahtijeva velike količine označenih podataka za treniranje modela.

Drugi oblik je segmentacija slike, gdje se razdvajaju različite namirnice unutar istog obroka, što je ključno za dobru procjenu, ali korišteni algoritmi mogu imati visoke potrebe za računalnim resursima (npr. računalnom memorijom). Nakon razdvajanja namirnica slijedi procjena volumena hrane na temelju trodimenzionalnog modela. Najčešće iz njih dobivamo precizne informacije o volumenu pojedinog dijela, međutim zahtijevaju složene algoritme te prikladnu dodatnu računalnu opremu za obavljanje izračuna.

Regresijski modeli koriste prikupljene podatke te na osnovu njih procjenjuju kalorijske vrijednosti. Njihova prednost je što ne zahtijevaju puno podataka kao duboko učenje, niti modele hrane za procjenu volumena, a puno su jednostavniji nego segmentacijski algoritmi. S druge strane, upitna je njihova točnost, ali na to se da utjecati njihovim podešavanjem te odabirom prikladnih značajki slika.

Problem procjene kalorijske vrijednosti hrane može se predstaviti kao regresijski problem unutar domene nadziranog strojnog učenja. U regresijskom problemu, cilj je predvidjeti kontinuiranu izlaznu varijablu (u ovom slučaju, kalorijsku vrijednost) na temelju ulaznih značajki

(karakteristika slike hrane). Model uči iz skupa označenih podataka kako bi predvidio kalorijske vrijednosti za nove, neoznačene slike hrane. Ključni izazovi uključuju osiguravanje točnosti predikcija, rukovanje raznolikošću hrane i precizno kvantificiranje volumena i sastojaka na slici.

Procjena kalorijske vrijednosti hrane iz slika predstavlja značajan napredak u polju nutricionizma i zdravstva. Korištenje nadziranog strojnog učenja i računalnog vida nudi automatski, precizan i učinkovit način praćenja unosa hrane, što može pomoći korisnicima u održavanju zdrave prehrane i životnog stila. Napredak u ovoj tehnologiji i daljnja istraživanja obećavaju još veću preciznost i dostupnost ovih alata u budućnosti.

2.2. Regresija kao zadatak nadziranog strojnog učenja

Nadzirano strojno učenje je vrsta strojnog učenja gdje je cilj odrediti nepoznatu funkcionalnu ovisnost između ulaznih veličina i izlazne veličine na temelju označenih podatkovnih primjera. Podatkovni primjeri su parovi koji se sastoje od vektora ulaznih veličina i vrijednosti izlazne veličine. Često se ulazne veličine nazivaju značajke (engl. *features*), a izlazna veličina oznaka. Nepoznata ovisnost aproksimira se modelom koji se kasnije koristi za predikciju izlazne veličine za nepoznate podatke.

Ako je izlazna veličina diskretna, tada se problem naziva klasifikacijski problem. S druge strane, ako je izlazna veličina kontinuirana, tada se problem nadziranog učenja naziva regresijski problem.

Algoritam strojnog učenja predstavlja primjenu dostupnih metoda koje „uče“ informacije iz podataka. S povećanjem broja primjera, oni se poboljšavaju. Otkrivaju obrasce u podacima – najčešće s ciljem predviđanja izlaznih vrijednosti iz ulaznih varijabli. Postupkom treniranja procjenjuju se parametri na temelju podatkovnih primjera. Prema [2], treniranje je proces pružanja podataka algoritmu strojnog učenja kako bi se pomoglo identificirati i naučiti dobre vrijednosti za sve uključene parametre.

Prema [3], algoritam strojnog učenja treba analizirati pomoću tri glavne komponente:

1. Model: skup hipoteza parametriziranih vektorom parametara.
2. Funkcija pogreške: ocjenjuje predviđanje modela. Ako postoje poznati primjeri, može napraviti usporedbu s ciljem utvrđivanja performansi modela.
3. Optimizacijski postupak: parametri modela se procjenjuju i optimiziraju do trenutka u kojem se dostignu željene performanse.

U poznate algoritme nadziranog učenja spadaju stabla odlučivanja (engl. *decision tree*, DT), *k*-najbližih susjeda (engl. *k-nearest neighbours*, KNN), linearna regresija, neuronska mreža te stroj

potpornih vektora (engl. *support vector machine*, SVM). Stablo odlučivanja, kao što sam naziv implicira, sastoji se od čvorova, grana i listova te se pomoću njih izvode pravila odlučivanja izvedenih iz značajki podatkovnih primjera. k -najbližih susjeda procjenjuje vrijednost izlazne veličine na temelju k najbližih podatkovnih primjera. Linearna regresija modelira kao linearnu kombinaciju odnos između jedne ili više ulaznih veličina s izlaznom veličinom. Neuronska mreža svoju primjenu pronalazi u složenim nelinearnim regresijskim zadacima. SVM maksimizira marginu između klasa ukoliko su klase linearno odvojive. Oblik SVM za regresijske probleme naziva se regresija potpornih vektora (engl. *Support Vector Regression*, SVR). Prema [4], cilj SVR modela u strojnom učenju je pronaći funkciju koja približno opisuje odnos između ulaznih varijabli i kontinuirane izlazne varijable, pri čemu nastoji minimizirati pogrešku predikcije.

Procjena performansi regresijskog modela uključuje korištenje različitih mjera vrednovanja, koje pomažu u razumijevanju koliko je model precizan. Neke od najčešće korištenih mjera jesu:

- a) Srednja kvadratna pogreška (engl. *Mean Squared Error*, MSE) je mjera prosječne kvadratne razlike između predviđenih vrijednosti i stvarnih vrijednosti izlazne veličine, odnosno

$$MSE = \frac{1}{n} \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2, \quad (2-1)$$

gdje n predstavlja broj primjera, $y^{(i)}$ stvarnu vrijednost, a $\hat{y}^{(i)}$ procjenu modela.

- b) Srednja apsolutna pogreška (engl. *Mean Absolute Error*, MAE), odnosno

$$MAE = \frac{1}{n} \sum_{i=1}^n |y^{(i)} - \hat{y}^{(i)}|, \quad (2-2)$$

je prosječna apsolutna razlika između predviđenih vrijednosti i stvarnih vrijednosti izlazne veličine. Što je MAE manji, to je model bolji.

- c) Srednja apsolutna postotna pogreška (engl. *Mean Absolute Percentage Error*, MAPE), odnosno

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y^{(i)} - \hat{y}^{(i)}|}{\max(\epsilon, |y^{(i)}|)}, \quad (2-3)$$

je prosječna apsolutna postotna razlika između predviđenih vrijednosti i stvarnih vrijednosti izlazne veličine. Što je MAPE manji, to je model bolji. gdje se uvodi novi

parametar ϵ koji predstavlja mali pozitivni broj kojim se sprječava mogućnost dijeljenja s 0.

Regresija je ključni zadatak nadziranog strojnog učenja s primjenama u mnogim područjima, uključujući procjenu kalorijske vrijednosti hrane iz slika. Razumijevanje osnovnih pojmova, algoritama i mjera vrednovanja ključno je za uspješno korištenje strojnog učenja u regresijskim zadacima. Treniranje modela uključuje korištenje skupa podataka za prilagodbu parametara modela, a vrednovanje performansi pomaže u razumijevanju koliko je model učinkovit u predviđanju izlaznih vrijednosti.

Kada govorimo o korištenju nadziranog strojnog učenja, ono podrazumijeva treniranje modela na temelju skupa podataka koji se sastoje od slika hrane i pripadnih kalorijskih vrijednosti. Proces je moguće podijeliti u nekoliko koraka:

1. Prikupljanje i označavanje podataka
2. Izgradnja modela: korištenje različitih algoritama za izgradnju modela koji procjenjuju kalorijsku vrijednost iz slika hrane.
3. Vrednovanje modela: nakon treniranja modela, potrebno je testirati njegove performanse na posebnom skupu podataka s ciljem utvrđivanja njegove točnosti i sposobnosti generalizacije na nove slike hrane.

2.3. Pregled literature

Procjena kalorijske vrijednosti hrane iz slika je složen problem koji zahtijeva napredne metode strojnog učenja i računalnog vida. Kroz proteklih nekoliko godina, istraživači su predložili različite pristupe za rješavanje ovog problema, koristeći razne podatkovne skupove, tehnike predobrade i algoritme strojnog učenja. Ovaj pregled literature daje uvid u najčešće korištene metode i tehnologije u ovom području.

Beijbom et al. su u [5] imali tzv. „poluautomatski“ i „automatski“ pristup. Poluautomatski pristup podrazumijevao je korisnikov odabir obroka na osnovu baze podataka i lokacije na kojoj se nalazi, dok s druge strane automatski pristup nije imao potrebe za nikakvim odabirom. Metoda se odnosi se na restoranske scenarije, tj. obroci u bazi podataka su napravljeni kao da su posluženi u specifičnom restoranu. Postiže se to da nema potrebe vršiti identifikaciju pojedinačne stvari, nego se gleda cijeli obrok i ne treba vršiti procjenu volumena hrane. Kada govorimo o korištenoj bazi podataka (*Menu-Match dataset*), autori su samostalno skupljali slike obroka iz nekoliko lokalnih restorana (azijskog, talijanskog i restorana gdje se poslužuju juhe) pomoću skupine fotografa sa

specifičnim uputama. Ukupno se sastoji od 646 slika, 1386 označenih prehrambenih proizvoda u 41 kategoriji. Precizne kalorijske vrijednosti odredio je nutricionista. Prilikom prikupljanja značajki, korišteno je 5 metoda za izdvajanje značajki: boja, HOG (engl. *histogram of oriented gradients*), SIFT (engl. *scale-invariant feature transforms*), LBP (engl. *local-binary patterns*) te rezultati filtriranja MR8. Dobivene značajke su kasnije iskorištene za treniranje SVM i SVR algoritama. Ova metoda postiže prosječnu pogrešku procjene kalorija od -21 ± 11.6 i apsolutnu pogrešku od 232 ± 7.2 .

Myers et al. su u [6] svoju metodu započinjaju sa detekcijom obroka na slici. Uzima se skup podataka iz [7] koji se sastoji od 101 klase hrane, 1000 slika svake klase (raspoređeno 750 za trening, 250 za testiranje). Ovaj skup podataka je stvoren za višeklasnu klasifikaciju, stoga je kombinirana sva hrana u jednu generičku klasu i tako nastaje problem binarne klasifikacije. Svaka slika je skalirana na dimenziju 512×512 i novi skup podataka dobiva naziv *Food101-Background*. Klasifikator za ovaj model je treniran na *GoogleNet* modelu i imao je preciznost od 99.02%. Nakon toga, uzeli su [7] skup podataka i iz njega stvorili *Food201-MultiLabel* koji je imao 201 značajku po slici. Model je treniran kao i ranije. Sljedeći korak je procjena volumena hrane koja je izvršena pomoću konvolucijske neuronske mreže. Konačni korak je procjena kalorija, međutim zbog manjka kalorijskih vrijednosti sastojaka pripremljene hrane nije izvršeno testiranje modela.

Manal Chokr i Shady Elbassuoni su u [8] koristili skup podataka koji se sastoji od slika hrane koje pripadaju preko 13 kategorija. Iz tog skupa izdvojili su 1132 slike i smjestili ih u pet tipova. Za izdvajanje značajki korišten je poseban alatni okvir za obradu slika. S ciljem smanjenja trajanja treniranja, svaka slika je skalirana na 4% inicijalne veličine i posvijetljena. Potom su provučene kroz alat koji dovodi do preko 11 tisuća značajki po slici. Smanjenje broja značajki omogućeno je sa informacijskom dobiti (engl. *InfoGain*), potom analizom glavnih komponenti (engl. *Principal Component Analysis*, PCA), koja se smatra najčešće korištenom metodom za navedeni posao. Nakon PCA, ostalo je 23 značajke za prikaz svake slike. Kako bi se odredio tip hrane, dobivene značajke se provlače kroz klasifikator koji određuje tip hrane i ta informacija se kasnije koristi u procjeni kalorija. Pored toga, model dobiva informaciju o masi hrane na slici. Ukoliko postoji podatak iz restorana iz kojeg potiče hrana o masi hrane, ta informacija se predaje. Ukoliko ne postoji, podatak se uzimao iz najpopularnijih lanaca brze hrane. Trenirano je nekoliko vrsta klasifikatora, ali se SVM pokazao kao najbolji za klasifikaciju hrane sa preciznošću od 0.991. Kada govorimo o procjeni mase, Najbolje se pokazao slučajna šuma (engl. *random forest*) model sa srednjom apsolutnom pogreškom od 2.75 grama. Kod procjene kalorija, višeslojni perceptron

(engl. *Multilayer Perceptron*) se pokazao najboljim sa srednjom apsolutnom pogreškom od 0.0933 na testnom skupu.

Yanchao Liang i Jianhua Li su u [9] stvorili metodu koja uzima 2 slike obroka, svaka slika ima kalibracijski objekt koji se koristi za procjenu faktora skaliranja slike. Hrana i kalibracijski objekt se otkrivaju sa konvolucijskom neuronskom mrežom, a *GrabCut* algoritmom se ocrtavaju rubovi pojedinog dijela hrane. Volumen hrane se procjenjuje putem formula. Na kraju slijedi procjena kalorija. Navedena metoda testirana je na podatkovnom skupu koji se sastoji od 19 vrsta hrane. Za kalibracijski objekt koristi se novčić. Preciznost konvolucijske neuronske mreže je 93%, dok je preciznost SVM 75.9% u detekciji objekata. Procjena volumena i mase hrane je najčešće blizu stvarnih vrijednosti, isto tako i procjena kalorija, što dovodi do zaključka da je ova metoda efektivna.

2.4. Kritički osvrt

Jedan od ključnih izazova u literaturi, koji nije dovoljno istražen, je nedostatak javno dostupnih skupova podataka koji sadrže slike obroka i pripadajuće informacije o kalorijskoj vrijednosti. Iako postoji mnogo baza podataka sa slikama hrane, većina ne uključuje informacije o kalorijama. Također, metode koje izravno procjenjuju kalorijsku vrijednost iz slika gotovo da ne postoje jer većina procjena temelji se na masi, volumenu ili povezivanju sa stavkama na poznatom jelovniku. Ovaj nedovoljno istražen pristup predstavlja važnu smjernicu za daljnje istraživanje, unatoč složenosti postupka.

Prilikom analize dostupne literature, može se doći do zaključka da ne postoji opće rješenje za sve moguće obroke, jer algoritmi trenirani na [5], [6], [8], [9] imaju ograničen broj različite hrane na raspolaganju. Pristup u [5] je jedini pristup u kojem nema procjene volumena sastojaka, nego se direktno vrši procjena kalorijske vrijednosti, što olakšava implementaciju, međutim može doći do velikih odstupanja. U [6] se ne izvršava konačna procjena kalorijskih vrijednosti, već se samo radi klasifikacija sastojaka, ali visoke preciznosti. U [8] se uz veliku preciznost procjenjuje masa obroka i na osnovu nje kalorijske vrijednosti. U [9] izostavljeno je objašnjenje postupka izračunavanja kalorija nakon procjene volumena.

Iako su različiti pristupi pokazali određene stupnjeve uspjeha, postoje i izazovi koji ostaju. Duboke neuronske mreže su se pokazale vrlo učinkovitim u prepoznavanju hrane, no njihova točnost može biti ograničena kvalitetom i raznolikošću podataka, isto tako zahtijeva velike količine podataka, što može predstavljati prepreku. Segmentacija slike, iako korisna, može biti izazovna zbog složenih pozadina i preklapajućih objekata.

Jedan od ključnih problema je varijabilnost u prezentaciji hrane, kao što su različite veličine porcija, kutovi snimanja i osvjetljenje. Augmentacija podataka može pomoći, ali ne rješava u potpunosti ove izazove. Osim toga, procjena kalorijske vrijednosti zahtijeva ne samo prepoznavanje hrane, već i točnu kvantifikaciju porcija, što dodatno komplicira problem.

3. OSTVARENO PROGRAMSKO RJEŠENJE

U ovom poglavlju je detaljno prikazan cjelokupni proces razvoja programskog rješenja za procjenu kalorijske vrijednosti hrane pomoću slika, uz korištenje strojnog učenja. Prvo je opisan korišteni podatkovni skup, koji je posebno razvijen za potrebe ovog rada, a sadrži slike obroka s pripadajućim oznakama kalorijskih vrijednosti za svaku sliku. Kroz sljedeće dijelove, analizirani su algoritmi za izdvajanje relevantnih značajki iz slika, kao i metode za odabir najvažnijih značajki koje utječu na točnost procjene. Na slici 3.1. prikazan je sažet dijagram koraka od kojih se sastoji predloženo rješenje.



Slika 3.1. Dijagram koraka predloženog rješenja

Izrada skupa podataka označava prikupljanje i pripremu slika hrane s odgovarajućim kalorijskim vrijednostima. Izdvajanje značajki je postupak izdvajanja značajki algoritmima za izdvajanje značajki iz slika. Na temelju izdvojenih značajki vrši se izgradnja modela koji procjenjuje količinu kalorija sa slike. Na kraju se koriste algoritmi odabira značajki te se ponovno treniraju regresijski modeli.

3.1. Izrada skupa podataka

Tijekom istraživanja koje je prethodilo ovom radu, analizirani su dostupni skupovi podataka koji bi omogućili preciznu procjenu kalorijske vrijednosti hrane iz slika. Međutim, niti jedan od postojećih podatkovnih skupova nije ispunjavao specifične zahtjeve istraživanja. Naime, većina postojećih skupova sadrži slike hrane, ali nisu dosljedno organizirani niti popraćeni preciznim podacima o kalorijskim vrijednostima. Većina dostupnih podatkovnih skupova sadrži opće slike obroka, bez odvojenih slika pojedinačnih namirnica s pripadajućim dokumentom koji sadrži kalorijske vrijednosti svake specifične namirnice na slici. Takva struktura bila je ključna za razvoj rješenja temeljenog na strojnom učenju koje može precizno prepoznati pojedinačne namirnice, kao i njihove kalorijske vrijednosti, bilo da su prikazane posebno ili u kombinacijama s drugim namirnicama.

Zbog toga se pristupilo samostalnom prikupljanju podataka, kako bi se stvorio podatkovni skup koji zadovoljava specifične potrebe ovog istraživanja. Skup podataka sastoji se od više od 160 slika koje predstavljaju skup često korištenih namirnica, kao i njihovih kombinacija. Cilj je bio


osigurati dovoljno slika za treniranje i testiranje modela, a pritom obuhvatiti različite scenarije koji se mogu pojaviti u stvarnim životnim uvjetima, kao što su varijacije u osvjetljenju, kutovima slikanja, te kombinacije više namirnica unutar jednog obroka.

Skup podataka je strukturiran tako da sadrži slike sljedećih namirnica: jabuka, banana, grah, kruh, kupus, mrkva, jaja, grožđe, limun, meso, naranča, paprika, breskva, pizza i rajčica. Pored slika pojedinačnih namirnica, postoji poseban dio slika s kombinacijama gore navedenih namirnica, npr. jaja i rajčica, meso i kupus i sl. Slike su organizirane na način da svaka od navedenih namirnica ima 10 slika, što omogućuje bolju distribuciju između podskupova za treniranje i testiranje unutar modela strojnog učenja i na ovaj način osigurana je raznovrsnost podataka.


U svrhu boljeg razumijevanja strukture podatkovnog skupa, svaka slika je jasno numerirana i raspoređena u pripadajući direktorij koji označava vrstu namirnice. Slika 3.2. i slika 3.3. prikazuju dva primjera direktorija sa jednom namirnicom (jabuke, banane), dok slika 3.4. prikazuje direktorij s kombinacijama namirnica.



Slika 3.2. Primjer direktorija „*apples*“



Slika 3.3. Primjer direktorija „*bananas*“



Slika 3.4. Direktorij s kombinacijama namirnica

Ovakav pristup omogućuje lakšu navigaciju kroz podatkovni skup, ali i olakšava proces treniranja modela jer su slike jasno kategorizirane i označene.

Za svaku sliku unutar podatkovnog skupa postoji prateći dokument koji sadrži informacije o kalorijskoj vrijednosti svake namirnice ili kombinacije namirnica prikazanih na slici. Proces prikupljanja kalorijskih podataka bio je temeljit kako bi se osigurala što veća točnost. Nakon što je svaka namirnica fotografirana, njena masa je izmjerena koristeći precizne digitalne vage. Na temelju tih mjerenja, kalorijska vrijednost svake namirnice izračunata je koristeći dostupne nutritivne tablice koje se mogu pronaći na provjerenim izvorima na internetu, npr. [10], gdje je moguće pronaći količinu kalorija za traženu namirnicu na 100 grama ili po porciji. Kalorije su računane na način da se za svaku namirnicu na temelju njene mase i energetske sadržaja u gramima izračunava ukupan broj kalorija.

Na primjer, ako se radi o banani mase 120 grama, koristeći podatak da 100 grama banane sadrži 89 kalorija, jednostavnim proračunom došlo se do brojke od približno 107 kalorija za tu sliku. Ovaj postupak ponovljen je za svaku sliku pojedinačno, čime se osigurala točna kalorijska vrijednost za sve slike unutar podatkovnog skupa. Ovakav sustav omogućava precizno treniranje modela koji može koristiti ove informacije za predikciju kalorijske vrijednosti novih slika.

Namirnice obuhvaćene ovim podatkovnim skupom pažljivo su odabrane na temelju njihove učestalosti korištenja u svakodnevnoj prehrani. Pored slika pojedinačnih namirnica, podatkovni skup također sadrži slike kombinacija tih namirnica, što omogućuje modelu da nauči prepoznavati kompleksnije obroke i njihovu kalorijsku vrijednost. Na taj način omogućava se realističnija simulacija stvarnih obroka u stvarnim uvjetima.

Cilj ovog pristupa bio je stvoriti raznoliku bazu podataka koja može podržati treniranje modela za prepoznavanje hrane u različitim uvjetima i različitim kombinacijama, čime bi se povećala točnost procjena kalorijske vrijednosti obroka u praksi. Novi skup podataka predstavlja važan dio ovog istraživanja, jer omogućuje treniranje modela strojnog učenja za procjenu kalorijske vrijednosti. Raznovrsnost slika, preciznost podataka o kalorijama i jasna struktura čine ovaj podatkovni skup izuzetno korisnim za potrebe istraživanja.

3.2. Odabir algoritama za procjenu kalorijske vrijednosti

Prilikom istraživanja algoritama za procjenu kalorijske vrijednosti, pokazalo se da su k -najbližih susjeda (eng. *k-nearest neighbours*, KNN), regresija potpornih vektora (eng. *Support Vector Regression*, SVR) i stablo odluke (eng. *Decision Tree*, DT) algoritmi pogodni za procjenu kalorijskih vrijednosti iz slika hrane jer svaki od njih nudi različite prednosti.

Algoritam KNN radi tako da za svaki novi primjer u skupu podataka pronalazi nekoliko najbližih primjera iz trening skupa te koristi njihove vrijednosti za predikciju. Kod problema procjene kalorijske vrijednosti, KNN koristi prosječne kalorijske vrijednosti ovih najbližih primjera kako bi predvidio kalorije za novi primjer. Ključni parametar kod KNN algoritma je broj susjeda (k), koji direktno utječe na točnost predikcije. Previše susjeda može dovesti do prevelikog utjecaja raznovrsnih primjera, dok premalo susjeda može rezultirati previsokim utjecajem šuma u podacima. Stoga je optimalan broj susjeda potrebno pronaći eksperimentiranjem i testiranjem različitih vrijednosti na konkretnom skupu podataka.

SVR je algoritam koji nastoji pronaći funkciju koja najbolje predviđa kalorijske vrijednosti unutar određenog raspona. Za razliku od KNN-a, SVR pokušava definirati granice unutar kojih predikcija ostaje što točnija. Jedan od ključnih parametara kod SVR-a je jezgra (engl. *kernel*), koja određuje način na koji se podaci transformiraju prije nego što model nauči odnose među njima. Postoje razne jezgre, npr. linearna, polinomijalna ili radijalna, a izbor jezgre ovisi o prirodi problema i raspodjeli podataka.

DT dijeli podatke na temelju značajki kako bi minimizirao grešku i donio predikciju. DT radi tako da postavlja odluke u obliku čvorova, gdje svaki čvor predstavlja pitanje o određenoj značajki, a grane iz tog čvora predstavljaju odgovore koji vode prema konačnoj odluci. Ključni parametar kod stabla odlučivanja je dubina stabla, koja određuje koliko detaljno stablo može učiti iz podataka. Prevelika dubina može dovesti do prekomjernog učenja, gdje model postaje previše prilagođen trening podacima i loše generalizira nove primjere. S druge strane, premala dubina može rezultirati nedovoljno detaljnim modelom koji ne može precizno donijeti odluke. Zbog toga je važno eksperimentirati s različitim dubinama stabla kako bi se postigla optimalna složenost modela.

3.3. Postupci za izdvajanje značajki

Prema [11], izdvajanje značajki (eng. *feature extraction*) je proces u strojnom učenju i analizi podataka koji uključuje identifikaciju i izdvajanje relevantnih značajki iz sirovih podataka. Te se značajke koriste za stvaranje informativnijeg skupa podataka, koji se dalje koristi za zadatke poput klasifikacije, predikcije i sl.

Postoji mnogo metoda za izdvajanje značajki, uključujući glavnu komponentnu analizu (eng. *Principal Component Analysis*, PCA), transformaciju značajki neovisnu o skali (eng. *Scale-Invariant Feature Transform*, SIFT) i ubrzane robusne značajke (eng. *Speeded-Up Robust*

Features, SURF). Međutim, u ovom radu su odabrane tri popularne i jednostavne metode: histogram orijentiranih gradijenata (eng. *Histogram of Oriented Gradients*, HOG), lokalni binarni obrasci (eng. *Local Binary Patterns*, LBP) i linearna diskriminantna analiza (eng. *Linear Discriminant Analysis*, LDA).

Prema [12], HOG opisuje oblik i strukturu objekata koristeći gradijente intenziteta unutar slike. Ključni parametri uključuju veličinu ćelija i blokova te broj orijentacija gradijenata. Manje ćelije pružaju precizniju analizu lokalnih detalja, dok veće ćelije hvataju globalne informacije. Prema [13], LBP se temelji na uspoređivanju svakog piksela sa susjednim pikselima i stvarajući binarne kodove. Najvažniji parametar je veličina susjedstva, gdje veće susjedstvo hvata složenije teksture, a manje detaljnije teksture jednostavnijih uzoraka. Prema [14], LDA se koristi za smanjenje dimenzionalnosti. Ključni parametar je broj komponenti koje se zadržavaju, a preporučuje se optimizacija tog broja kako bi se postigla što bolja točnost bez gubitka važnih informacija.

Ove tri metode odabrane su zbog njihove jednostavnosti implementacije i učinkovitosti u analizi slika, što ih čini pogodnim za zadatak procjene kalorijskih vrijednosti. Parametri svake metode mogu se prilagoditi u skladu sa specifičnostima skupa podataka, kako bi se optimizirala točnost i performanse modela.

3.4. Predobrada skupa podataka odabirom značajki

Prema [15], odabir značajki (eng. *feature selection*) je proces odabira najvažnijih značajki koje će se koristiti u algoritmima strojnog učenja. Tehnike odabira značajki smanjuju broj ulaznih varijabli eliminacijom suvišnih ili nebitnih značajki te se usredotočuju na one najrelevantnije za model. Glavne prednosti uključuju jednostavnije modele, kraće vrijeme treniranja, izbjegavanje „prokletstva visoke dimenzionalnosti“, koje se odnosi na niz problema koji se javljaju kada radimo s podacima koji imaju veliki broj značajki itd. Najčešće metode odabira značajki uključuju analizu glavnih komponenti (eng. *Principal Component Analysis*, PCA), ugrađene metode (eng. *embedded methods*) i sekvencijalnu eliminaciju značajki (eng. *Recursive Feature Elimination*, RFE).

Međutim, zbog jednostavnosti implementacije i primjene, u ovom radu odabrane su informacijska dobit (eng. *Information Gain*, InfoGain), Chi-kvadrat test (eng. *Chi-Square*, Chi2) i omotač (eng. *wrapper*). Prema [16], InfoGain se koristi za mjerenje koliko svaka značajka doprinosi smanjenju nesigurnosti u predikcijama ciljne varijable. Ova metoda izračunava razliku u entropiji između skupa podataka prije i nakon uvođenja značajke. Ključni parametar ovdje je prag informacijske

dobiti, koji se postavlja kako bi se eliminirale značajke koje ne pridonose dovoljno preciznim predikcijama. Viši prag rezultirat će eliminacijom više značajki, dok će niži prag zadržati više značajki u modelu.

Prema [17], Chi-kvadrat test koristi se za procjenu neovisnosti između kategorijskih značajki i ciljne varijable. Ova metoda izračunava statističku povezanost između svake značajke i ciljne varijable, rangirajući značajke prema njihovoj Chi-kvadrat vrijednosti. Parametar koji se prilagođava je prag Chi-kvadrat vrijednosti; značajke koje imaju niže vrijednosti smatraju se nebitnima. Prag treba odabrati na temelju skupa podataka, pri čemu veći prag eliminira više značajki, a manji zadržava one koje imaju manji, ali ipak važan utjecaj. Prema [18], omotač se temelji na korištenju modela za procjenu značajki kroz iterativni postupak, gdje se značajke uklanjaju ili dodaju u model kako bi se maksimizirala točnost predikcija. Glavni parametri koje je potrebno prilagoditi uključuju izbor modela koji će se koristiti kao procjenitelj i kriterij za dodavanje ili uklanjanje značajki. Ova metoda je precizna, ali može biti računalno zahtjevna, stoga je važno balansirati između točnosti i brzine izvođenja.

4. EKSPERIMENTALNA ANALIZA I REZULTATI

U ovom poglavlju su prikazani rezultati dobiveni programskim rješenjima. Kako bi se procijenila kvaliteta modela, provedeni su eksperimenti u kojima su korišteni različiti skupovi značajki i parametri. Rezultati svakog pokusa bit će prikazani u tablicama, gdje je metrika RMSE korištena za procjenu performansi modela. Ova metrika omogućuje detaljnu analizu odstupanja predviđenih kalorijskih vrijednosti od stvarnih vrijednosti, s ciljem utvrđivanja najboljeg modela u kontekstu procjene kalorija iz slika hrane.

4.1. Postavke i metodologija eksperimentalne analize

Zbog hardverskih ograničenja prilikom razvoja i treniranja modela, sav kod u ovom radu pisan je i izveden na platformi *Google Colab*. *Colab* omogućava korištenje besplatnih resursa poput GPU-ova i TPU-ova, što znatno ubrzava proces treniranja modela, posebno kod rada s velikim količinama podataka i složenim algoritmima strojnog učenja. *Colab* je platforma koja omogućuje pokretanje tzv. „bilježnica“ putem interneta, bez potrebe za lokalnom instalacijom softvera ili naprednim hardverskim resursima. Programsko rješenje nalazi se u prilogu [4.1].

Prvi dio implementacije sastoji se od uporabe ranije spomenutih algoritama za izdvajanje značajki HOG, LBP i LDA, njihovo spremanje te treniranje modela na osnovu dobivenih značajki. Prvi korak je raspakiranje podatkovnog skupa, nakon toga učitavanje izlazne varijable (kalorijskih vrijednosti) u potrebnom formatu. U toku rada, primijećeno je da algoritmi ne obrađuju slike redom kojim su složene u podatkovnom skupu, stoga je posebnom metodom osigurano da se to ne događa. Potom, svaka slika se smanjuje na veličinu 128x128 i pretvara u sivu skalu (eng. *grayscale*), s ciljem smanjenja složenosti. Zatim slijedi izdvajanje značajki, skaliranje podataka i pohrana dobivenih značajki. Ovim postupcima iz slika je izdvojeno ukupno 8127 različitih značajki.

Uz pomoć značajki dobivenih u prvom dijelu koda, istrenirani su modeli strojnog učenja. Prilikom podjele na trening i test skup, veličina trening skupa je bila 70%, dok je veličina testnog skupa bila 30%. Također, za metodu podjele podataka na trening i testni skup zadano je 10 različitih početnih stanja, stoga je eksperiment ponavljan 10 puta. Nakon treniranja, izračunate su osnovne mjere vrednovanja (MSE, RMSE, MAE, MAPE), s posebnom pažnjom na mjeru RMSE i rezultati su spremljeni.

Zatim se pokušao pristup u kojem su modeli trenirani zasebno na HOG, LBP i LDA značajkama. Za svaki postupak isprobano je nekoliko različitih parametara i traženi su „najbolji“ parametri,

koji su se uspoređivali uz pomoć mjere RMSE. „Najbolji“ parametri pojedinih algoritama su povezani, te su s njima trenirani regresijski modeli s različitim parametrima. U tablici 4.1. nalaze se isprobani parametri.

Tablica 4.1. Testirani parametri algoritama za izdvajanje značajki

	HOG	LBP	LDA
Parametri	1. pikseli po ćeliji: (8, 8), ćelije po bloku: (2, 2) 2. pikseli po ćeliji: (8, 8), ćelije po bloku: (2, 2)	1. polumjer: 1, broj susjeda: 8 2. polumjer: 2, broj susjeda: 16	1. broj komponenti: 1 2. broj komponenti: 2

U nastavku implementacije provedeno je podešavanje hiperparametara regresijskih algoritama s RMSE mjerom kao mjerom kvalitete. Za svaki algoritam je odabrana mreža od 10-ak hiperparametara, koji su prikazani u tablici [4.2], te su vrednovane pomoću unakrsne validacije (eng. *cross validation*) metode. Najbolji parametri su iskorišteni za treniranje i testiranje, te su prikazani rezultati mjere RMSE za slike s jednom, dvije i tri namirnice, redom. Na kraju su upotrijebljeni ranije spomenuti algoritmi za odabir značajki (InfoGain, Chi-kvadrat i omotač, odvojeno), ponovno su iskorišteni dobiveni parametri za treniranje i testiranje, te su prikazani rezultati mjere RMSE redom za slike s jednom, dvije i tri namirnice.

Tablica 4.2. Testirani hiperparametri modela

	KNN	SVR	DT
Parametri	1. Broj susjeda: [3,5,7,9,11] 2. Težine (utjecaj susjeda): [uniformna, udaljenost]	1. Jezgre: [linearna, radijalna, polinomijalna] 2. Regulacijski parametar (C): [0.1, 1, 10, 100]	1. Maksimalna dubina: [3,5,10,None] 2. Minimalni broj uzoraka za podjelu: [2,5,10]

4.2. Usporedba postupaka za izdvajanje značajki

U ovom potpoglavlju prikazani su rezultati treniranja regresijskih algoritama nakon izdvajanja značajki. Tablica 4.3. prikazuje mjeru RMSE nakon prvog izdvajanja značajki, tj. uporabe algoritama za izdvajanje značajki, povezivanje dobivenih značajki i treniranja modela.

Tablica 4.3. RMSE vrijednosti nakon izdvajanja svih značajki i treniranja modela

Redni br. izvođenja	SVR	KNN	DT
1	263.79	219.72	291.49
2	267.58	239.42	315.01
3	219.56	202.05	312.82
4	269.50	232.11	338.09
5	200.67	187.65	276.39
6	216.05	197.11	293.66
7	184.39	154.87	269.37
8	206.56	226.99	280.48
9	272.19	232.61	332.77
10	244.37	201.49	268.12
Prosjek	234.47	209.40	297.82
Medijan	231.97	210.89	292.58
Standardna devijacija	31.14	24.67	24.23

Iz tablice 4.3 možemo uočiti da model KNN pokazuje najniže prosječne RMSE vrijednosti (209.40), što sugerira da daje najtočnije procjene u odnosu na SVR i DT modele, čiji su prosjeci 234.47 i 297.82, redom. Standardna devijacija je najmanja kod KNN-a (24.67), kao i medijan, što znači da ovaj model pokazuje najmanje varijabilnosti u procjenama, čime je pouzdaniji u ponovljenim izvođenjima. Na osnovu toga, KNN model se pokazuje kao najbolji izbor u ovom slučaju.

U tablici 4.4. prikazan je prosječni rezultat mjere RMSE nakon više izvođenja eksperimenta i nakon treniranja modela na značajkama dobivenim posebno iz HOG, LBP i LDA algoritmima za izdvajanje značajki sa najboljim parametrima algoritma.

Tablica 4.4. Vrijednosti RMSE nakon pojedinačnog izdvajanja značajki i treniranja

	Parametri	SVR	KNN	DT
HOG	pikseli po ćeliji: (16, 16), ćelije po bloku: (2, 2)	321.10	188.44	289.82
LBP	polumjer: 1, broj susjeda: 8	321.57	152.14	192.89
LDA	broj komponenti: 1	308.73	233.43	319.66

Na temelju tablice 4.4. dolazi se do zaključka kako KNN model najbolje procjenjuje kalorijsku vrijednost koristeći značajke dobivene iz sva tri algoritma za izdvajanje značajki (HOG, LBP i LDA). Međutim, važno je naglasiti da su sve metode, uključujući KNN, pokazale relativno loše performanse, jer je značajna greška napraviti procjenu koja je manja ili veća za gotovo 200 kalorija od ispravne vrijednosti, što je u kontekstu prehrambenih procjena neprihvatljivo. Iz tablice 4.4 možemo zaključiti da LBP značajke daju najbolje rezultate za KNN i DT modele, dok HOG značajke pružaju solidne performanse za KNN. LDA, iako uspješna kod KNN modela, pokazuje veće pogreške kod DT i SVR modela, što dovodi do zaključka da LDA možda nije idealan algoritam za ovaj zadatak u cjelini.

Uspoređujući tablicu 4.3 i tablicu 4.4, možemo vidjeti da kombinacija značajki daje nešto bolje rezultate za KNN i SVR modele u odnosu na pojedinačne metode izdvajanja značajki. Na primjer, prosječni RMSE za KNN u tablici 4.3 iznosi 209.40, dok je najbolji rezultat za KNN s pojedinačnim metodama (LBP) 152.14 u tablici 4.4. Iako LBP daje bolji rezultat od kombinacije, kod SVR i DT modela kombinirane značajke pokazuju bolje ukupne performanse. To govori da pojedinačne metode mogu biti bolje u nekim slučajevima.

4.3. Usporedba algoritama za procjenu kalorijskih vrijednosti

U ovom potpoglavlju prvo su prikazani rezultati eksperimenta u kojem su se trenirali regresijski modeli s različitim parametrima, te su prikazani odnosi onih koji za svoj model imaju najmanju vrijednost RMSE. Pored toga, imamo prikaz rezultata eksperimenta u kojem je za svaki model zadana mreža od 10-ak hiperparametara te su na osnovu postupka unakrsne validacije i mjere RMSE određeni najbolji i isti korišteni za treniranje i testiranje. Na kraju, dostupan je uvid u

rezultate dobivene za slike koje na sebi imaju jednu, dvije i tri namirnice. Uz prikaz rezultata, napisani su i zaključci koji se mogu izvući iz dobivenih rezultata.

U tablici 4.5. vidljiv je prikaz odnosa RMSE vrijednosti za one regresijske modele koji su se pokazali najboljima. Za treniranje modela korištene su sve značajke dobivene iz algoritama za izdvajanje značajki HOG, LBP i LDA, a parametri modela su također dostupni na uvid.

Tablica 4.5. Prikaz odnosa najboljih modela na osnovu RMSE na validacijskom skupu

	Parametri	RMSE
SVR	jezgra = polinomijalna	234.73
KNN	broj_susjeda = 3	179.42
DT	dubina = 3	238.80

Rezultati ovog eksperimenta pokazuju kako KNN model opet daje najmanje pogreške u odnosu na ostala dva algoritma. Isto tako, DT opet ima najveće vrijednosti mjere vrednovanja. U nastavku je prikaz tablice 4.6. koja prikazuje rezultate dobivene na testnom skupu nakon obavljanja unakrsne validacije.

Tablica 4.6. Prikaz odnosa najboljih modela na osnovu RMSE nakon unakrsne validacije

	Parametri	RMSE
SVR	jezgra = polinomijalna	200.86
KNN	broj_susjeda = 7	177.74
DT	dubina = 10	244.74

Rezultati ovog eksperimenta ponovo govore kako KNN model najbolje procjenjuje izlaznu varijablu, tj. kalorijske vrijednosti obroka sa slike. Tablica 4.7. prikazuje vrijednosti RMSE za pojedinačne slike sa jednom, dvije i tri namirnice, redom za svaki model.

Tablica 4.7. Prikaz vrijednosti RMSE za jednu, dvije i tri namirnice na slici

	Parametri	Jedna namirnica	Dvije namirnice	Tri namirnice
SVR	jezgra: polinomijalna	2.57	147.84	6.49
KNN	broj_susjeda: 11	0.29	147.75	4.62

DT	dubina: 3	153.13	149.39	5.97
----	-----------	--------	--------	------

Iz rezultata ovog eksperimenta moguće je zaključiti kako je došlo do pretjeranog usklađivanja modela kod rezultata za tri namirnice. Dokaz za to su male vrijednosti RMSE za sva tri algoritma kod slika s tri namirnice. Dodatan razlog za male vrijednosti RMSE kod slika s tri namirnice može biti nedovoljan broj različitih slika s takvom formom za treniranje i testiranje.

4.4. Analiza učinka odabira značajki

Posljednji eksperimenti treniranja regresijskih modela učinjeni su nakon obavljanja odabira značajki sa tri ranije spomenuta algoritma, a to su InfoGain, Chi-kvadrat i omotač. Prilikom implementacije omotača, potrebno je odabrati tzv. „strategiju“ kojom će se obavljati odabir značajki, a u programskom rješenju korištena je slijedna pretraga unaprijed (engl. *Sequential Forward Selection*, SFS) pristup. SFS je algoritam za odabir značajki koji radi tako da iterativno dodaje značajke u model. Počinje s praznim skupom značajki i u svakom koraku dodaje onu značajku koja najviše poboljšava performanse modela. Taj postupak se ponavlja sve dok dodavanje novih značajki ne poboljšava značajno performanse modela.

Tablica 4.8. prikazuje vrijednosti parametra RMSE treniranih modela za svaki oblik slika, tj. slike s jednom, dvije i tri namirnice nakon uporabe InfoGain algoritma za 10, 20 i 50 posto od ukupnog broja značajki.

Tablica 4.8. Vrijednosti RMSE za trenirane modele nakon InfoGain odabira značajki

	Broj značajki	Jedna namirnica	Dvije namirnice	Tri namirnice
SVR	10% (177)	241.33	435.59	416.22
KNN	10% (177)	234.06	304.68	414.80
DT	10% (177)	350.16	387.90	427.81
SVR	20% (355)	237.72	437.95	417.45
KNN	20% (355)	239.91	336.58	414.71
DT	20% (355)	302.22	363.08	408.02
SVR	50% (887)	231.70	451.58	421.97
KNN	50% (887)	255.11	349.01	414.71
DT	50% (887)	316.18	510.52	418.65

Rezultati eksperimenta pokazuju kako najbolje procjene u prosjeku dobivamo DT modelom, bez obzira na broj značajki. Isto tako, primjetna je bolja procjena slika s dvije namirnice u odnosu na ostale modele. S druge strane, najlošije procjene daje SVR model, za svaku vrstu slike.

U tablici 4.9. nalazi se prikaz dobivenih rezultata treniranja modela nakon uporabe Chi-kvadrat algoritma za odabir značajki.

Tablica 4.9. Vrijednosti RMSE za trenirane modele nakon Chi-kvadrat odabira značajki

	Broj značajki	Jedna namirnica	Dvije namirnice	Tri namirnice
SVR	10% (177)	229.03	338.89	9.90
KNN	10% (177)	225.46	434.64	14.87
DT	10% (177)	308.14	361.57	15.26
SVR	20% (355)	225.10	343.27	9.77
KNN	20% (355)	236.01	434.64	14.88
DT	20% (355)	270.48	45.79	15.26
SVR	50% (887)	208.93	350.85	9.84
KNN	50% (887)	222.89	434.64	14.88
DT	50% (887)	298.77	643.10	15.89

Iz rezultata dobivenih ovim eksperimentom vidljiv je porast pogreške kod DT modela prilikom povećavanja broja susjeda, što u prethodnom eksperimentu nije bio slučaj. Sličnost vrijednosti kod slika s tri namirnice je uzrokovana sličnošću slika u podatkovnom skupu. U tablici 4.10. prikazan je ispis istih vrijednosti kao i u prethodne dvije tablice, ali ovaj put nakon korištenja omotača. Zbog duljine trajanja izvođenja omotača i ograničenih računalnih resursa, broj značajki koje su korištene je smanjen na 3 različite vrijednosti, tj. 50, 200 i 400.


Tablica 4.10. Vrijednosti RMSE za trenirane modele nakon odabira značajki pomoću omotača

	Broj značajki	Jedna namirnica	Dvije namirnice	Tri namirnice
SVR	50	247.72	331.03	11.71
KNN	50	174.89	434.64	12.71
DT	50	321.58	362.14	15.89
SVR	200	246.86	331.06	11.68
KNN	200	158.73	436.71	12.71
DT	200	306.26	640.10	17.19

SVR	400	245.24	331.06	11.68
KNN	400	206.55	331.06	12.03
DT	400	300.27	363.16	19.89

Iz analize tablice proizlazi da KNN model pokazuje najbolje performanse u predviđanju kalorijske vrijednosti jedne namirnice, s najmanjim RMSE vrijednostima u svim slučajevima, čime nadmašuje SVR i DT modele. Nasuprot tome, SVR model se pokazuje najpouzdanijim za predikciju kalorijske vrijednosti dvije i tri namirnice, gdje održava stabilne RMSE vrijednosti, osobito u slučaju tri namirnice, gdje postiže izuzetno niske vrijednosti. S druge strane, DT model općenito ima najveće RMSE vrijednosti u svim kategorijama, što ukazuje na slabije performanse u odnosu na KNN i SVR modele. Iako se DT model poboljšava s povećanjem broja značajki, i dalje zaostaje za ostalim modelima, osobito u predikciji dvije i tri namirnice.

U nastavku na slici 4.1. prikazan je dijagram pravokutnika (engl. *box plot*) za KNN regresijski algoritam, ostatak dijagrama moguće je pronaći u prilogu [4.2]. Dijagram pravokutnika predstavlja grafički prikaz koji se koristi za vizualizaciju raspodjele numeričkih podataka. Prikazuje osnovne statističke informacije o skupu podataka, uključujući medijan, tj. središnju vrijednost podataka, kvartile: donji (Q1) i gornji (Q3), koji predstavljaju vrijednosti od koje su 25% podataka manje, te 75% podataka manje, raspon, tj. udaljenost između minimuma i maksimuma (osim stršućih vrijednosti) te stršće vrijednosti (engl. *outliers*) koje značajno odstupaju od ostatka podataka.



Slika 4.1. Prikaz dijagrama pravokutnika KNN modela

Iz dijagrama pravokutnika na slici se može zaključiti da KNN model najbolje radi s najmanjim i najvećim brojem značajki, dok srednji rasponi značajki dovode do povećanja RMSE. To govori da pažljiv odabir broja značajki i parametara algoritama može značajno utjecati na performanse modela i da optimalne performanse nisu uvijek postignute s većim brojem značajki.

5. ZAKLJUČAK

Cilj ovog završnog rada bio je izgraditi model koji na temelju slike obroka može izračunati broj kalorija, koristeći metode strojnog učenja, izdvajanja i odabira značajki. Programsko rješenje oslanjalo se na specifičan podatkovni skup sastavljen za potrebe istraživanja, dok su različiti algoritmi za izdvajanje i odabir značajki korišteni kako bi se optimizirale performanse modela. Iako su rezultati pokazali određeni napredak, nisu bili dovoljno precizni da bi se model mogao smatrati potpuno uspješnim, što je jasno vidljivo kroz mjeru RMSE, koja se koristila za ocjenu performansi modela.

Za izdvajanje značajki iz slika korišteni su sljedeći algoritmi: HOG, LBP i LDA, dok su za odabir značajki korišteni: InfoGain, Chi-kvadrat te omotač slijedne pretrage unaprijed.

Rezultati su pokazali da trenutni podatkovni skup i modeli ne pružaju dovoljno precizne procjene kalorijske vrijednosti obroka, što se može vidjeti kroz relativno visoke vrijednosti RMSE. Iako su ovi rezultati ispod očekivanja, rad je postavio temelj za buduća istraživanja i optimizacije.

Jedan od glavnih razloga nedovoljne preciznosti modela je relativno mali i ograničen podatkovni skup od okvirno 160 slika s pripadnim kalorijskim vrijednostima. Preporučuje se proširenje podatkovnog skupa s većim brojem slika koje pokrivaju veći skup namirnica, kao i slike koje sadrže složenije kombinacije više namirnica na istom tanjuru. Također, važno je osigurati detaljne i precizne informacije o količini kalorija za svaku sliku, kako bi treniranje modela bilo što točnije i pouzdanije.

Dodatno, istraživanje naprednijih regresijskih algoritama i metoda za izdvajanje i odabir značajki može dovesti do značajnog poboljšanja performansi modela. Specifično, trebalo bi ispitati mogućnost korištenja složenijih algoritama poput dubokog učenja (eng. *deep learning*), koji su se u mnogim područjima pokazali izuzetno učinkovitim. Osim toga, optimizacija parametara postojećih algoritama, kao i istraživanje novih pristupa u odabiru značajki, može pomoći u daljnjem poboljšanju preciznosti modela.

Zaključno, ovaj rad predstavlja prvi korak u razvoju sustava za automatsku procjenu kalorijske vrijednosti hrane iz slika, ali je jasno da daljnji rad i istraživanja na ovom području mogu doprinijeti značajnom napretku i omogućiti stvaranje praktičnih alata koji bi olakšali praćenje prehrane u svakodnevnom životu. Kako bi se poboljšala točnost i pouzdanost predloženog rješenja, potrebno je proširiti podatkovni skup s raznovrsnim slikama različitih obroka i namirnica, čime bi se model trenirao na više podataka. Dodatno istraživanje različitih regresijskih modela i optimizacija njihovih parametara mogla bi značajno poboljšati modele. Također, važno je dublje istražiti algoritme za izdvajanje i odabir značajki, kako bi se odabrale one koje najviše doprinose preciznosti procjene kalorijske vrijednosti iz slika.

LITERATURA

- [1] M. Chen, K. Dhingra, W. Wu, L. Yang, R. Sukthankar, J. Yang, PFID: Pittsburgh Fast Food Image Dataset, Columbia University, 2009.
- [2] Oden Technologies, What is Model Training: What is Model Training in Machine Learning [online], Oden Technologies, Ujedinjeno Kraljevstvo, 2024, dostupno na: <https://oden.io/glossary/model-training/> [1.9.2024.]
- [3] J., Šnajder, Osnovni koncepti, str. (9-10), UNIZG FER, Zagreb, 2022.
- [4] Alakh, Support Vector Regression Tutorial for Machine Learning: What is a Support Vector Machine?, Analytics Vidhya, kolovoz 2023, dostupno na: <https://www.analyticsvidhya.com/blog/2020/03/support-vector-regression-tutorial-for-machine-learning/> [1.9.2024.]
- [5] O. Beijbom, N. Joshi, D. Morris, S. Saponas, S. Khullar, Menu-Match: Restaurant-Specific Food Logging from Images, Microsoft Research and University of California, San Diego, str. (847-848), 2015.
- [6] A. Myers, N. Johnston, V. Rathod, A. Korattikara, A. Gorban, N. Silberman, S. Guadarrama, G. Papandreou, J. Huang, K. Murphy, Im2Calories: Towards an Automated Mobile Vision Food Diary, ICCV, 2015.
- [7] Food101, Tensorflow, dostupno na: <https://www.tensorflow.org/datasets/catalog/food101> [27.6.2024.]
- [8] M. Chokr, S. Elbassuoni, Calories Prediction from Food Images, American University of Beirut, 2017.
- [9] Y. Liang, J. Li, Deep Learning-Based Food Calorie Estimation Method in Dietary Assessment, School of Information Science and Engineering, East China University of Science and Technology, 2018.
- [10] Calories in Food: Calorie Chart Database [online], 2024, dostupno na: <https://www.calories.info/> [1.9.2024.]
- [11] Feature Extraction: Why is Feature Extraction Important? [online], Domino Data Lab, 2024, dostupno na: <https://domino.ai/data-science-dictionary/feature-extraction> [2.9.2024]

- [12] A. Singh, Feature Engineering for Images: A Valuable Introduction to the HOG Feature Descriptor: Introduction to the HOG Feature Descriptor [online], Analytics Vidhya, 2024, dostupno na: <https://www.analyticsvidhya.com/blog/2019/09/feature-engineering-images-introduction-hog-feature-descriptor/> [2.9.2024.]
- [13] A. Ihalapathirana, Understanding the Local Binary Pattern (LBP): A Powerful Method for Texture Analysis in Computer Vision [online], Medium, 2023, dostupno na: <https://aihalapathirana.medium.com/understanding-the-local-binary-pattern-lbp-a-powerful-method-for-texture-analysis-in-computer-4fb55b3ed8b8> [2.9.2024.]
- [14] J. Zhou, Q. Zhang, S. Zeng, B. Zhang, L. Fang, Latent Linear Discriminant Analysis for feature extraction via Isometric Structural Learning: Abstract [online], Elsevier, 2023, dostupno na: <https://www.sciencedirect.com/science/article/abs/pii/S0031320323009159> [2.9.2024.]
- [15] Feature Selection: What is Feature Selection [online], Heavy.ai, 2024, dostupno na: <https://www.heavy.ai/technical-glossary/feature-selection> [5.9.2024.]
- [16] K. Qu, J. Xu, Q. Hou, K. Qu, Y. Sun, Feature selection using Information Gain and decision information in neighborhood decision system: Abstract [online], Elsevier, 2023, dostupno na: <https://www.sciencedirect.com/science/article/abs/pii/S1568494623001187> [5.9.2024.]
- [17] K. Raval, Chi-Square Test for Feature Selection in Machine Learning: How is the Chi-Square Test used for Feature Selection? [online], LinkedIn, 2024, dostupno na: <https://www.linkedin.com/pulse/chi-square-test-feature-selection-machine-learning-ketan-raval-uscqc> [5.9.2024.]
- [18] A. Muhandisin, Understanding Wrapper Methods in Machine Learning: The importance of Feature Selection [online], Medium, 2023, dostupno na: <https://arismuhandisin.medium.com/understanding-wrapper-methods-in-machine-learning-a-guide-to-feature-selection-23f71059abf8> [5.9.2024.]

SAŽETAK

Glavni cilj ovog završnog rada bio je razviti model za procjenu kalorijske vrijednosti hrane koristeći nadzirano strojno učenje i slike obroka. U tu svrhu izrađen je specifičan podatkovni skup koji sadrži slike najčešćih namirnica i obroka, zajedno s pripadajućim kalorijskim vrijednostima. Ključni korak u razvoju modela bilo je izdvajanje značajki iz slika korištenjem algoritama kao što su HOG, LBP i LDA. Kako bi se poboljšala preciznost modela, implementirane su i metode za odabir značajki, uključujući informacijsku dobit, Chi-kvadrat test i omotač. Modeli trenirani za procjenu kalorijske vrijednosti obuhvaćali su algoritme k -najbližih susjeda (KNN), regresiju potpornih vektora (SVR) i stabla odlučivanja (DT). Iako su rezultati pokazali određene potencijale, model nije postigao dovoljnu preciznost, što je vidljivo kroz relativno visoke vrijednosti mjere RMSE. Uzrok tome dijelom je ograničenost korištenog podatkovnog skupa, ali i složenost problema prepoznavanja hrane s jedne slike. Unatoč tome, ovaj rad pruža vrijedan uvid u problematiku procjene kalorija iz slika te postavlja temelje za buduća istraživanja. U budućnosti je preporučljivo proširiti podatkovni skup, uključiti složenije obroke te istražiti naprednije metode strojnog učenja, poput dubokog učenja, kako bi se poboljšala preciznost modela i omogućila njegova primjena u svakodnevnom životu korisnika.

Ključne riječi: izdvajanje značajki, kalorije, nadzirano učenje, regresija, slike hrane

ABSTRACT

FOOD CALORIES ESTIMATION USING SUPERVISED MACHINE LEARNING

The main goal of this thesis was to develop a model for estimating the caloric value of food using supervised machine learning and food images. For this purpose, a specific dataset was created containing images of the most common food items and meals, along with their respective caloric values. A key step in the development of the model was feature extraction from images using algorithms such as HOG, LBP, and LDA. To improve model accuracy, feature selection methods were also implemented, including Information Gain, Chi-Square test, and Wrapper method. The models trained for estimating caloric values included k-nearest neighbors (KNN), support vector regression (SVR), and decision trees (DT). Although the results showed some potential, the model did not achieve satisfactory accuracy, as evidenced by relatively high RMSE values. The causes for this are partly due to the limitations of the dataset used, as well as the complexity of recognizing food from a single image. Nonetheless, this thesis provides valuable insights into the issue of calorie estimation from images and lays the foundation for future research. In the future, it is recommended to expand the dataset, include more complex meals, and explore advanced machine learning methods such as deep learning, to improve the accuracy of the model and enable its application in everyday user scenarios.

Keywords: calorie estimation, feature extraction, food images, regression, supervised learning

ŽIVOTOPIS

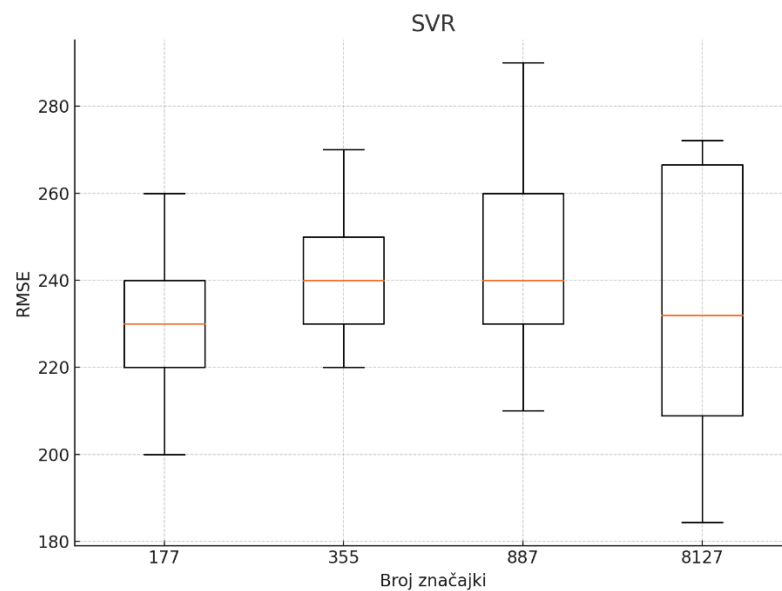
Danilo Petrović rođen je 26. listopada 2001. godine u Vukovaru, gdje započinje svoje obrazovanje u Osnovnoj školi "Nikola Andrić". Nakon osnovne škole, nastavlja sa srednjoškolskim obrazovanjem u Gimnaziji Vukovar, gdje otkriva svoj interes za nastavkom obrazovanja u tehničkim znanostima. Nakon završetka gimnazije, upisuje Fakultet elektrotehnike, računarstva i informacijskih tehnologija u Osijeku 2020. godine, gdje započinje svoje visoko obrazovanje na prijediplomskom sveučilišnom studiju računarstva.

PRILOZI


4.1. Izvorni kod aplikacije

Dostupno: <https://gitlab.com/danilo.petrovic.vu/food-calories-estimation.git>

4.2. Dijagrami pravokutnika



Slika 4.2. Prikaz dijagrama pravokutnika SVR modela



Slika 4.3. Prikaz dijagrama pravokutnika DT modela